

ОГЛЯДИ ЛІТЕРАТУРИ

Український журнал клінічної хірургії. 2025 Травень/Червень; 92(3):62-66
DOI: 10.26779/2786-832X.2025.3.62

Штучний інтелект і радіологічна діагностика в гепатології

М. М. Колотілов, В. В. Солодущенко, Б. А. Тарасюк, В. С. Березенко

Всеукраїнський центр материнства та дитинства НАМН України, м. Київ

Термін «штучний інтелект» (ШІ) було запропоновано в 1956 році Джоном Маккарті, американським вченим, засновником функціонального програмування [1]. Це загальна назва для різних стратегій, що передбачають самостійну імітацію когнітивних функцій людини, включаючи самонавчання та пошук рішень без заздалегідь заданого алгоритму, і отримання результатів, порівнянних із результатами інтелектуальної діяльності людини. Машинне навчання (МН) як підрозділ ШІ охоплює автоматизовані процедури для формування загальних правил із набору даних, тобто правил, що виводяться системою на основі прикладів [1], та виконується за допомогою заздалегідь визначених алгоритмів або штучних нейронних мереж. Існує контрольоване (з учителем) та неконтрольоване (без учителя) МН. Контрольоване МН передбачає, що приклади містять вхідні дані та відповідні очікувані результати (наприклад, результати класифікації, діагностичні зображення пухлин). Неконтрольоване МН полягає в тому, що система самостійно визначає можливі результати на основі лише вхідних даних. Метою МН є прогнозування результатних даних на основі навчальних вхідних даних. Типові завдання МН у радіології – це класифікація, сегментація зображень, регресія та кластеризація [2]. Наприклад, контрольоване МН для радіологічної діагностики базується на серії позначених радіологом зображень органа та верифікованих патогістологічних висновків, таких як, наприклад, холангіокарцинома.

Математика, закладена в технології ШІ (процес МН, математичний пошук оптимальних рішень систем рівнянь), дозволяє знаходити та запам'ятовувати характерні патерни в отриманих даних, які не завжди можуть бути інтерпретовані людиною. Математична модель ШІ – це функція з незалежними змінними (предикторами) та параметрами, підібраними під час МН.

Глибоке навчання (ГН) – це сукупність методів МН (з учителем, із частковим залученням учителя, без учителя, з підкріпленням), що базуються на загальному, а не на вузькоспеціалізованому аналізі інформації [1, 2]. ГН простіше у виконанні, ніж МН, високоточне й економічно ефективне.

Радіоміка слугує основою для МН і ГН [1, 2]. Цифрове діагностичне зображення складається з масиву цифр, що відтворює практично всі фізико-хімічні та біологічні властивості біооб'єкта з певним ступенем деформації, пов'я-

заної з особливостями технології (дискретизація, квантування, фільтрація) отримання зображення піксельної чи воксельної структури [1]. Радіоміка – це сукупність методів обчислювального витягнення з цифрового діагностичного зображення біооб'єкта за допомогою алгоритмів МН і ГН практично всіх його фізико-хімічних і біологічних кількісних характеристик з певним ступенем похибки. Наприклад, при радіомічному дослідженні дифузійно-зважених зображень магнітно-резонансної томографії (МРТ) гепатоцелюлярної карциноми (ГЦК) за допомогою безкоштовного програмного забезпечення 3D Slicer Radiomics (www.slicer.org) з відкритим кодом для візуалізації, обробки, сегментації, реєстрації та аналізу біомедичних 3D зображень, планування операційної навігації було отримано 74 радіомічні ознаки, які включали 19 статистичних ознак першого порядку та 55 текстурних ознак [3].

Особливо інформативне застосування радіоміки для аналізу текстур діагностичних зображень, що визначаються як відмінності в інтенсивності відтінків сірого в зоні інтересу та пов'язані з внутрішньопухлинною гетерогенністю [1, 2], яка містить потенційно клінічно значущу інформацію, що могла б залишитися непоміченою.

Перспективне застосування ШІ в медицині, де ці технології стали очевидно успішними і вже активно й ефективно застосовуються для аналізу різних діагностичних зображень – рентгенографія, МРТ, комп'ютерна томографія (КТ), сонографія (СГ), позитронно-емісійна томографія (ПЕТ), однофотонна емісійна комп'ютерна томографія (ОФЕКТ) – у рамках основних завдань діагностики: виявлення, розпізнавання уражень, сегментація, квазігістопатологічна ідентифікація (прогнозування ризику розвитку тієї чи іншої патології), класифікація/регресія та оптимізація/реконструкція зображень [1, 2]. Сегментація включає окреслення меж усього органа та осередка ураження (наприклад, контурів пухлини) або інших структур, що становлять інтерес для клініциста. Як один з інструментів для сегментації використовують nnU-Net (No New U-Net) – базовий алгоритм моделі ШІ для семантичної сегментації, який автоматично адаптується до заданого набору даних, аналізує надані навчальні приклади й автоматично налаштовує обробку даних [4, 5]. Він може тестувати 2D і 3D зображення з довільними вхідними модальностями.

стями/каналами, враховує інтервали вокселів, гетерогенність, анізотропію, тестує 3D зображення розмірами від $40 \times 40 \times 40$ до $1500 \times 1500 \times 1500$ пікселів та 2D зображення розмірами від 40×40 до приблизно $30\,000 \times 30\,000$ пікселів. Варто зазначити, що виконання сегментації 2D зображення розмірами 512×512 пікселів триває менше однієї секунди в останніх версіях алгоритму.

Технології МН/ГН використовують для двох цілей: відтворення даних та автоматизації їх інтерпретації, що зазвичай виконують експерти-клініцисти, та витягнення тонких інформативних ознак зі складних даних, які не одразу сприймаються експертом-радіологом. Застосування моделей ШІ утримчує зменшує навантаження на радіологів і вгіятеро скорочує тривалість очікування діагнозу для пацієнта. Аналіз знімка триває 10 с, а точність діагностики сягає 80 – 95%.

Мета огляду – ознайомити з потенціалом і проблемами моделей ШІ у променевій діагностиці захворювань печінки.

Згідно з систематичним оглядом статей, опублікованих з 01.01.2018 по 29.10.2024 року у базах даних PubMed/Medline, Scopus і Web of Science щодо застосування ШІ у візуалізації печінки [6], їх розподіл за модальностями був таким: КТ – 51,54%, МРТ – 27,19%, СГ – 15,34%, мультимодальні технології – 3,32%, радіоізотопні технології – 1,70%, рентгенографія – 0,40%; у рамках деталізації мультимодальності: КТ+МРТ – 2,92%, КТ+СГ – 0,16%, КТ+СГ+МРТ – 0,16%, СГ+МРТ – 0,08%; за завданнями: класифікація – 58,68%, виявлення та/або сегментація – 26,70%, оптимізація зображення – 9,33%, багатозадачність – 5,27%; у рамках деталізації багатозадачності: виявлення та/або сегментація і класифікація – 4,95%, виявлення і класифікація – 0,24%, виявлення, сегментація і класифікація – 0,08%.

Необхідно зауважити, що КТ була основним методом візуалізації (51,54% статей), її використовували майже удвічі частіше, ніж МРТ (27,19%), і втричі частіше, ніж СГ (15,34%). Перевага КТ пояснюється кількома факторами: технологія використовує одиницю Хаунсфілда для вимірювання значень вокселів та має еталон, що забезпечує відносно стандартизовану і відтворювану міру для різних томографів. Натомість для МРТ немає аналогічного кількісного стандарту, хоча інтенсивність магнітно-резонансного сигналу може змінюватися залежно від типу томографа та протоколів візуалізації, а кількість наборів даних для МРТ і СГ обмежена. Також слід відмітити залежність даних для СГ від оператора.

Для забезпечення відтворюваності та прозорості моделей ШІ опубліковано керівні принципи їх розробки: контрольний список для ШІ в медичній візуалізації (CLAIM) [7], мінімальна інформація для звітності про медичний ШІ (MINIMAR) [8].

Біомедичні набори даних становлять основу моделювання ШІ і доступні на кількох онлайн-платформах або їх отримують від біологів і лікарів, які працюють у клініках і лабораторіях. Для навчання моделей ШІ завантажують від кількох сотень до кількох тисяч зображень, оброблених радіологами, хірургами чи терапевтами та ве-

рифікованих патоморфологами. Після «навчання» вона самостійно розпізнає відхилення на нових знімках і звертає на них увагу радіологів.

LiverHccSeg – загальнодоступний багатофазний набір даних МРТ із мануальною сегментацією пухлин печінки та ГЦК й аналізом узгодженості між сегментаціями: вік, стать, T1 – зважені зображення (33) 310 хворих; вік, стать, T2–33 318 хворих; вік, стать, T1–33 і T2–33 291 хворого; аналогічні дані 55 осіб контрольної групи [9]. Цей набір даних відображає всі складнощі та гетерогенність анатомічних зображень: контурну нодулярність, атрофію або гіпертрофію сегментів печінки, а також інші зміни, пов'язані з ускладненнями цирозу (асцит, варикозне розширення вен і спленомегалія). Зображення отримані на томографах двох виробників з індукцією 1,5 і 3Т. Сегментації печінки мають високу узгодженість: 0,95 (середнє значення) $\pm$ 0,01 (стандартне відхилення), а для сегментацій ГЦК характерна більша варіативність: 0,85 (середнє значення) $\pm$ 0,16 (стандартне відхилення).

Kaggle – це безкоштовна онлайн-платформа, що об'єднує вчених (Data Scientist) з усього світу для співпраці та навчання у вирішенні реальних проблем науки про дані, зокрема проблем, пов'язаних із моделями ШІ та їх застосуванням у клінічній практиці [10]. *Kaggle Datasets* дозволяє публікувати набори даних та ділитися ними у приватному або публічному режимі, надаючи ресурси для зберігання та обробки наборів даних, яких на сьогодні близько 330 тисяч. Водночас існують технічні обмеження: набір даних не може перевищувати 200 ГБ. Платформа забезпечує доступ до широкого спектра моделей МН, які користувач може фільтрувати за завданнями, наприклад, класифікація зображень чи виявлення об'єктів, а також за типом даних і фреймворком.

Архів зображень раку (The Cancer Imaging Archive – TCIA) – це база даних із відкритим доступом до верифікованих КТ, МРТ, ПЕТ, ОФЕКТ зображень (формат DICOM) злоякісних пухлин [1, 11]. Усі дані в цьому архіві знеособлені та організовані в колекції за гістотипом раку та/або його анатомічною локалізацією. Ресурси TCIA призначені для підтримки розробки методів комп'ютерної діагностики (кількісна візуалізація); оцінки об'єктивної відтворюваності наукових даних за допомогою стандартних статистичних методів; дослідження кореляції клінічних діагностичних медичних зображень із цифровими мікроскопічними гістологічними зображеннями; дослідження біомаркерів зображень; дослідження гетерогенності (між пацієнтами та внутрішньопухлинної); відстеження реакції тканин у динаміці спостереження – об'єктивного вимірювання прогресування пухлини; візуалізації та аналізу великого обсягу даних (клінічна симптоматика, гістопатологія, геноміка).

Відомо про багато онлайн-репозиторіїв для зберігання наборів даних. Їх якість об'єктивно оцінена в літературі [12].

Модель ШІ на основі кількісної СГ та еластографії для покращення класифікації ступеня стеатозу, ступеня за-

палення та стадії фіброзу печінки у пацієнтів із її хронічними захворюваннями порівняно з однією лише еластографією зсувної хвилі, яка використовується з гістопатологією як еталонним стандартом [13]. При розмежуванні ступенів стеатозу S0 і S1–3, S0–1 і S2–3, S0–2 і S3 значення площі під ROC – кривою (Receiver Operating Characteristic) AUC (Area Under the Curve) становили відповідно 0,60, 0,63 і 0,62, коли використовували лише еластографію, та 0,90, 0,81 і 0,78, коли використовували модель ШІ на основі СГ з еластографією; при розмежуванні ступенів запалення A0 і A1–3, A0–1 і A2–3, A0–2 і A3 значення AUC становили відповідно 0,56, 0,62 і 0,64 та 0,75, 0,68 і 0,69; при розмежуванні стадій фіброзу печінки F0 і F1–4, F0–1 і F2–4, F0–2 і F3–4, F0–3 і F4 – відповідно 0,66, 0,77, 0,72 і 0,74 та 0,72, 0,77, 0,77 і 0,75.

Оцінена чутливість моделі ШІ для виявлення метастазів у печінці [14], зокрема тих, яких не помітили радіологи. Набір даних: 746 пацієнтів із діагностованими метастазами в печінці (листопад 2010 – вересень 2017 року). Отримано зображення метастазів у 137 пацієнтів, у 68 із них вони класифіковані як «пропущені». Чутливість моделі для всіх типів уражень печінки, метастазів та метастазів, «пропущених» радіологами, становила 70,1, 70,8 і 55,0% відповідно. Модель ідентифікувала виявлені метастази печінки у 92,7% пацієнтів, «пропущені» – у 53,7% пацієнтів. Середня кількість хибнопозитивних результатів становила 0,48 на одного пацієнта.

Модель ШІ GAN для підвищення точності прогнозування ГЦК за рентгенівською щільністю [15] пройшла ГН (228 багатозонних КТ зображень 30 хворих із верифікованою ГЦК, 27 – без ГЦК) із п'ятикратною перехресною перевіркою. Досягнуто точність 91%, чутливість 93%, специфічність 88%. Тривалість аналізу при цьому становила 0,04 с.

Модель ШІ для оцінки ризику ГЦК у рамках класифікації LI–RADS (Liver Imaging Reporting and Data System), версія 2018 року з використанням самоналаштованого методу сегментації зображень на основі ГН nnU–Net [16]. В основу ГН покладені МРТ верифіковані зображення уражень категорій LR–3 і вище у 602 хворих із ГЦК і мануальна сегментація зображень уражень категорій LR–3, LR–4, LR–5 або LR–M. Набір моделей U–Net із 14 входними каналами був навчений за допомогою фреймворку nnU–Net для автоматичної сегментації. Виявлення пухлин, їх класифікація за LI–RADS і метрики сегментації були розраховані шляхом постобробки вихідних даних семантичної сегментації остаточного ансамблю моделей. Для зовнішньої оцінки використовувалася модифікована версія набору даних LiverHccSeg. Остаточні когорти навчання, внутрішнього і зовнішнього тестів включали 383, 219 і 16 пацієнтів відповідно. У трьох когортах хворих ураження за LI–RADS категорій LR–3 і вище і LR–M 10 мм і більше були виявлені з чутливістю 0,41–0,85, 0,40–0,90 і 0,83 відповідно (для LR–5: 0,85, 0,90 і 0,83 відповідно) і позитивними прогностичними значеннями 0,70–0,94, 0,67–0,88 і 0,90 відповідно (для LR–5: 0,94, 0,88 і 0,90 відповідно).

Модель ШІ для сегментації печінки на T1–33 МРТ [17]. Розглянуто 3 різні архітектури ГН (nnUNet, PocketNet, Swin UNETR) із використанням даних (819 T1–33), отриманих із 6 географічно різних установ.

Модель ШІ на основі глибокої радіоміки до- та післяопераційної багатопараметричної МРТ (бпМРТ) для прогнозування локальної прогресії пухлини (ЛПП) після термічної абляції (ТА) при ГЦК [18]. Об'єкт: 417 хворих, ретроспективно зареєстрованих у трьох лікарнях. Сформовано одну первинну когорту – ПК (n=189) і дві зовнішні тестові когорти – ЗТК1 (n=135) і ЗТК2 (n=93). Характеристики радіоміки були отримані з T1–33, T2–33 і дифузійно – зважених зображень (1668 послідовностей і 31 536 багатопараметричних зрізів) за допомогою моделі ResNet18. Інтегративна модель ШІ (сигнатура бпМРТ із клініко–патологічними змінними) була побудована для стратифікації ризику ЛПП. Абляційний край, множинні пухлини та пухлина, що прилягала до великих судин, розглядалися як фактори ризику ЛПП. Ефективність моделей порівнювали за значеннями AUC з використанням тесту Делонга. Значення AUC моделі бпМРТ становили 0,864 у ПК, 0,843 у ЗТК1 і 0,858 у ЗТК2, що було значно вище, ніж у клінічній моделі ($p < 0,001$). Після інтеграції змін клінічних результатів відбулося значне покращення моделі бпМРТ: значення AUC становили 0,870–0,869 у трьох когортах ($p < 0,001$ для всіх), що уможливило стратифікацію ризику для загальної виживаності хворих. Модель бпМРТ має важливе значення для визначення ризику ЛПП у хворих із ГЦК після ТА та прийняття персоналізованих рішень.

Модель ШІ для реконструкції 3D T1–33, використана для аналізу даних 50 хворих із вогнищевими ураженнями печінки [19], забезпечила значно вищу якість зображення, ніж якість звичайного зображення, у всіх фазах контрастування гадоксетовою кислотою ($p < 0,001$ для всіх), а також мала значно менше шумових і кільцевих артефактів, ніж звичайні зображення ($p < 0,05$ для всіх), і значно змінену текстуру зображення ($p < 0,001$ для всіх). Три радіологи незалежно оцінили якість зображення та розпізнавання уражень за 5–бальною шкалою. Показник розпізнавання уражень був значно вищим на зображеннях, реконструйованих за допомогою ГН, ніж на звичайних зображеннях в артеріальній фазі – 2,15 (95% довірчий інтервал 1,78 – 2,52) та 2,03 (95% довірчий інтервал 1,65 – 2,40) відповідно ($p = 0,036$), але значної різниці в портальній венозній та гепатобіліарній фазах не виявлено ($p > 0,05$ для всіх).

Модель ШІ для об'єктивної оцінки ризику трансплантації печінки, яка об'єднує клінічні дані з показниками кількісної гістології та МРТ радіоміки (87 хворих – ГН, 22 – тестування). Відомо, що трансплантація печінки ефективна в лікуванні ГЦК. Тільки у хворих із ГЦК менше 5 см можлива успішна трансплантація та більш тривале безрецидивне виживання. Модель розроблена для розширення можливості трансплантації у хворих із пухлиною більше 5 см, її точність становила 89% [20].

Моделі ШІ в діагностиці ГЦК. У всебічному огляді охоплено результати 183 розробок [21]. У всіх діагностичних модальностях повідомлене значення AUC у більшості моделей перевищувало 0,900. У моделях СГ у В-режимі та з контрастним підсиленням значення AUC були вищі – 0,947 і 0,957 відповідно. Модель ГН на основі даних КТ забезпечувала класифікацію злоякісних уражень печінки із значенням AUC 0,986. Використання моделі ШІ на основі даних МРТ для диференціації невеликих ГЦК від доброякісних уражень показало значення AUC 0,975.

Досліджено діагностичну ефективність моделі ШІ на основі ГН зі згортковою нейронною мережею (ЗНМ) для диференціації пухлин печінки при динамічній КТ із рентгеноконтрастуванням [22]. Використано набори КТ–зображень новоутворень печінки у процесі трифазного сканування. Новоутворення діагностували за п'ятьма категоріями: А – класичні ГЦК; В – злоякісні пухлини печінки, відмінні від класичних і ранніх ГЦК; С – невизначені утворення або утворення, схожі на інші новоутворення, включаючи ранні прояви ГЦК і диспластичні вузлики та рідкісні доброякісні утворення; D – гемангіоми; Е – кісти. Контрольоване навчання виконували з використанням 55 536 наборів зображень, отриманих у 2013 році (від 460 пацієнтів отримано 1068 наборів, цю кількість було збільшено у 52 рази – повернуті, зсунуті паралельно, сильно збільшені та з доданим шумом зображення створено з вихідних). ЗНМ була протестована з використанням 100 наборів зображень печінки, отриманих у 2016 році від 74 чоловіків та 26 жінок, середній вік яких становив ($66,4 \pm 10,6$) року; середній розмір новоутворення ($26,9 \pm 25,9$) мм; 21, 9, 35, 20 і 15 новоутворень печінки для категорій А, В, С, D і Е відповідно. Виконано п'ять сесій навчання та тестування. Розраховано точність категоризації новоутворень печінки за допомогою моделі ЗНМ і значення AUC для диференціації категорій А, В і С, Е. Медіана точності диференціальної діагностики новоутворень печінки для тестових даних становила 0,84. Середнє значення AUC для розмежування категорій А, В і С, Е становило 0,92 (зазвичай значення AUC від 0,9 до 1,0 відповідають відмінній диференціації, 0,8–0,9 – дуже добрій, 0,7–0,8 – добрій, 0,6–0,7 – середній, 0,5–0,6 – незадовільній, значення AUC 0,5 відповідає вгадуванню). ГН із ЗНМ показало високу діагностичну ефективність у диференціації пухлин печінки при динамічній КТ.

Варіанти аналізу текстури тканин, сегментації, методів постобробки дуже різноманітні та численні на різних платформах і в різних дослідженнях, що ускладнює порівняння результатів на державному рівні. Немає єдиних стандартів вимірювання показників радіоміки та текстури тканин. Незважаючи на статистично значущі результати, опубліковані дані не позбавлені широкого розкиду [23].

Інструменти ШІ, розроблені для одного регіону світу з використанням даних цього регіону, можуть виявитися непридатними для застосування в інших регіонах з іншою поширеністю захворювань, обмеженою інфраструктурою та іншими системами охорони здоров'я [24].

Відомо про етнічні відмінності у функціонуванні багатьох ферментних систем (зокрема ферментів метаболізму та детоксикації ксенобіотиків), що мають суттєве клінічне фармакогенетичне значення, а також про те, що деякі хвороби притаманні виключно певним етнічним групам [25].

Ефективна розробка моделей ШІ потребує наявності верифікованих у патогістологічному аспекті архівів діагностичних зображень, що постійно поповнюються. Алгоритми/моделі ШІ слід тестувати, використовуючи проспективно зібрані дані, щоб оцінити надійність функцій з урахуванням нових даних. Перед впровадженням у клінічну практику необхідні великі багатоцентрові дослідження. Конкретне застосування технологій ШІ дуже перспективне, але жодне застосування ШІ, яке пов'язане з гістопатологією, не було схвалено регуляторним органом. Клінічне впровадження методів МН і ГН у гепатології значно відрізняється від їх клінічного впровадження в інших галузях медицини. В українській радіології немає репозиторія верифікованих медичних діагностичних зображень.

Дослідження виконане у рамках науково–дослідної роботи «Розробити технологію цифрової обробки променево–діагностичних зображень на основі елементів штучного інтелекту при дифузній патології печінки у хворих різних вікових груп» (номер державної реєстрації 0120U000437).

Фінансування. Зовнішні джерела фінансування та підтримки не використовувалися. Гонорари чи інші компенсації не виплачувалися.

Внесок авторів. Усі автори зробили однаковий внесок у цю роботу.

Конфлікт інтересів. Авторів, які брали участь у цьому дослідженні, заявили, що вони не мають конфлікту інтересів щодо цього рукопису.

Згода на публікацію. Усі автори прочитали і схвалили остаточний варіант рукопису та дали згоду на його публікацію.

References

1. Yu KH, Healey E, Leong TY, Kohane IS, Manrai AK. Medical Artificial Intelligence and Human Values. *N Engl J Med*. 2024 May 30;390(20):1895–904. doi: 10.1056/NEJMra2214183. PMID: 38810186.
2. Berbis MA, Paulano Godino F, Royuela Del Val J, Alcalá Mata L, Luna A. Clinical impact of artificial intelligence–based solutions on imaging of the pancreas and liver. *World J Gastroenterol*. 2023 Mar 7;29(9):1427–45. doi: 10.3748/wjg.v29.i9.1427. PMID: 36998424; PMCID: PMC10044858.
3. Zhang J, Qiu Q, Duan J, Gong G, Jiang Q, Sun G, et al. Variability of radiomic features extracted from multi-b–value diffusion-weighted images in hepatocellular carcinoma. *Transl Cancer Res*. 2019 Feb;8(1):130–40. doi: 10.21037/ter.2019.01.14. PMID: 35116742; PMCID: PMC8798719.
4. Isensee F, Jaeger PF, Kohl SAA, Petersen J, Maier–Hein KH. nnU–Net: a self–configuring method for deep learning–based biomedical image segmentation. *Nat Methods*. 2021 Feb;18(2):203–11. doi: 10.1038/s41592-020-01008-z. Epub 2020 Dec 7. PMID: 33288961.
5. Zunair H, Ben Hamza A. Sharp U–Net: Depthwise convolutional network for biomedical image segmentation. *Comput Biol Med*. 2021

- Sep;136:104699. doi: 10.1016/j.combiomed.2021.104699. Epub 2021 Jul 29. PMID: 34348214.
6. Pomohaci MD, Grasu MC, Băicoianu-Nițescu AȘ, Enache RM, Lupescu IG. Systematic Review: AI Applications in Liver Imaging with a Focus on Segmentation and Detection. *Life* (Basel). 2025 Feb 8;15(2):258. doi: 10.3390/life15020258. PMID: 40003667; PMCID: PMC11856300.
7. Tejani AS, Klontzas ME, Gatti AA, Mongan JT, Moy L, Park SH, et al. Checklist for Artificial Intelligence in Medical Imaging (CLAIM): 2024 Update. *Radiol Artif Intell*. 2024 Jul;6(4):e240300. doi: 10.1148/ryai.240300. PMID: 38809149; PMCID: PMC11304031.
8. Hernandez-Boussard T, Bozkurt S, Ioannidis JPA, Shah NH. MINIMAR (MINimum Information for Medical AI Reporting): Developing reporting standards for artificial intelligence in health care. *J Am Med Inform Assoc*. 2020 Dec 9;27(12):2011–15. doi: 10.1093/jamia/ocaa088. PMID: 32594179; PMCID: PMC7727333.
9. Gross M, Arora S, Huber S, Küçükaya AS, Onofrey JA. LiverHccSeg: A publicly available multiphasic MRI dataset with liver and HCC tumor segmentations and inter-rater agreement analysis. *Data Brief*. 2023 Oct 10;51:109662. doi: 10.1016/j.dib.2023.109662. PMID: 37869619; PMCID: PMC10587725.
10. Shen X, Zhou Y, Shi X, Zhang S, Ding S, Ni L, et al. The application of deep learning in abdominal trauma diagnosis by CT imaging. *World J Emerg Surg*. 2024 May 6;19(1):17. doi: 10.1186/s13017-024-00546-7. PMID: 38711150; PMCID: PMC11071191.
11. Prior F, Smith K, Sharma A, Kirby J, Tarbox L, Clark K, et al. The public cancer radiology imaging collections of The Cancer Imaging Archive. *Sci Data*. 2017 Sep 19;4:170124. doi: 10.1038/sdata.2017.124. PMID: 28925987; PMCID: PMC5827108.
12. Chicco D, Fabris A, Jurman G. The Venus score for the assessment of the quality and trustworthiness of biomedical datasets. *BioData Min*. 2025 Jan 9;18(1):1. doi: 10.1186/s13040-024-00412-x. PMID: 39780220; PMCID: PMC11716409.
13. Destremes F, Gesnik M, Chayer B, Roy-Cardinal MH, Olivié D, Giard JM, et al. Quantitative ultrasound, elastography, and machine learning for assessment of steatosis, inflammation, and fibrosis in chronic liver disease. *PLoS One*. 2022 Jan 27;17(1):e0262291. doi: 10.1371/journal.pone.0262291. PMID: 35085294; PMCID: PMC8794185.
14. Nakai H, Sakamoto R, Kakigi T, Coeur C, Isoda H, Nakamoto Y. Artificial intelligence-powered software detected more than half of the liver metastases overlooked by radiologists on contrast-enhanced CT. *Eur J Radiol*. 2023 Jun;163:110823. doi: 10.1016/j.ejrad.2023.110823. Epub 2023 Apr 7. PMID: 37059006.
15. Wang Y, Jian W, Yuan Z, Guan F, Carlson D. Deep learning with attention modules and residual transformations improves hepatocellular carcinoma (HCC) differentiation using multiphase CT. *Prec Radiat Oncol*. 2025;9:13–22. <https://doi.org/10.1002/pro6.70003>.
16. Stollmayer R, Güven S, Heidt CM, Schlamp K, Kaposi PN, von Stackelberg O, et al. LI-RADS-based hepatocellular carcinoma risk mapping using contrast-enhanced MRI and self-configuring deep learning. *Cancer Imaging*. 2025 Mar 17;25(1):36. doi: 10.1186/s40644-025-00844-6. PMID: 40097992; PMCID: PMC11912691.
17. Patel N, Celaya A, Eltaher M, Glenn R, Savannah KB, Brock KK, et al. Training robust T1-weighted magnetic resonance imaging liver segmentation models using ensembles of datasets with different contrast protocols and liver disease etiologies. *Sci Rep*. 2024 Sep 9;14(1):20988. doi: 10.1038/s41598-024-71674-y. PMID: 39251664; PMCID: PMC11385384.
18. Chen C, Han Q, Ren H, Wu S, Li Y, Guo J, et al. Multiparametric MRI-based model for prediction of local progression of hepatocellular carcinoma after thermal ablation. *Cancer Med*. 2023 Sep;12(17):17529–40. doi: 10.1002/cam4.6277. Epub 2023 Sep 11. PMID: 37694337; PMCID: PMC10524055.
19. Yoon JH, Lee JE, Park SH, Park JY, Kim JH, Lee JM. Comparison of image quality and lesion conspicuity between conventional and deep learning reconstruction in gadoteric acid-enhanced liver MRI. *Insights Imaging*. 2024 Oct 28;15(1):257. doi: 10.1186/s13244-024-01825-2. PMID: 39466542; PMCID: PMC11519238.
20. He T, Fong JN, Moore LW, Ezeana CF, Victor D, Divatia M, et al. An imageomics and multi-network based deep learning model for risk assessment of liver transplantation for hepatocellular cancer. *Comput Med Imaging Graph*. 2021 Apr;89:101894. doi: 10.1016/j.compmedimag.2021.101894. Epub 2021 Mar 11. PMID: 33725579; PMCID: PMC8054468.
21. Chatzipanagiotou OP, Loukas C, Vailas M, Machairas N, Kykalos S, Charalampopoulos G, et al. Artificial intelligence in hepatocellular carcinoma diagnosis: a comprehensive review of current literature. *J Gastroenterol Hepatol*. 2024 Oct;39(10):1994–2005. doi: 10.1111/jgh.16663. Epub 2024 Jun 23. PMID: 38923550.
22. Yasaka K, Akai H, Abe O, Kiryu S. Deep Learning with Convolutional Neural Network for Differentiation of Liver Masses at Dynamic Contrast-enhanced CT: A Preliminary Study. *Radiology*. 2018 Mar;286(3):887–96. doi: 10.1148/radiol.2017170706. Epub 2017 Oct 23. PMID: 29059036.
23. Lambin P, Leijenaar RTH, Deist TM, Peerlings J, de Jong EEC, van Timmeren J, et al. Radiomics: the bridge between medical imaging and personalized medicine. *Nat Rev Clin Oncol*. 2017 Dec;14(12):749–62. doi: 10.1038/nrclinonc.2017.141. Epub 2017 Oct 4. PMID: 28975929.
24. Mun SK, Wong KH, Lo SB, Li Y, Bayarsaikhan S. Artificial Intelligence for the Future Radiology Diagnostic Service. *Front Mol Biosci*. 2021 Jan 28;7:614258. doi: 10.3389/fmolb.2020.614258. PMID: 33585563; PMCID: PMC7875875.
25. Yoshida H, Kiyuna T. Requirements for implementation of artificial intelligence in the practice of gastrointestinal pathology. *World J Gastroenterol*. 2021 Jun 7;27(21):2818–33. doi: 10.3748/wjg.v27.i21.2818. PMID: 34135556; PMCID: PMC8173389.

Надійшла 17.02.2025